

**PREDVIĐANJE CIJENA DIONICA NA TRŽIŠTU BOSNE I
HERCEGOVINE POMOĆU NEROSNKE MREŽE**

**THE PREDICTION OF MARKET PRICE SHARES OF BOSNIA AND
HERZEGOVINA BY USING NEURAL NETWORKS**

Aida Habul, Prof. Dr.
Ekonomski fakultet
Trg Oslobođjena 1
71 000 Sarajevo
aida.habul@efsa.unsa.ba

Emir Kremić, M.Sc.
International Burch
University
71 000 Sarajevo
k.emir@acm.org

Mirza Habul, B.Sc.
Ekonomski fakultet
Trg Oslobođjena 1
71 000 Sarajevo

REZIME

Ovaj rad ima za cilj da predstavi istraživanje o primjeni neuronskih mreža u predviđanju cijena dionica na tržištu Bosne i Hercegovine. Uz sposobnost otkrivanja uzoraka u nelinearnim i haotičnim sistemima, neuralne mreže nude mogućnost predviđanja na tržištu u odnosu na trenutnu tehnologiju. Zajednička analiza tržišta kao što je tehnička analiza, temeljna analiza te regresija i usporedba s neuronskim performansom mreža. Tako efikasnost funkcioniranja tržišta hipotetički je predstavljena u suprotnosti s teorijom neuronskih mreža. U radu je predstavljen neuronski model mreže, gdje smo nastojali da testiramo performanse vještačkog neuronskog modela u predviđanju cijena na tržištu.

Ključne riječi: Neuronske mreže, MATLAB, predviđanje

SUMMARY

The aim of this work is to present research of the application of neural networks for predicting stock prices in the market of Bosnia and Herzegovina. The ability to detect patterns in nonlinear and chaotic system, neural network does offer the ability to predict the market with current technologies. The joint analysis of the market, such as: technical analysis, fundamental analysis and the analysis of regression and comparison with neural networks performances. Thus, the efficiency of markets is presented hypothetically and it works opposite with neural network model. In this paper is shown the simple artificial neural network mode, moreover we have tried to test the performances of artificial neural network mode for predicting prices in the market.

Keywords: Neural networks, MATALAB, prediction

1. UVOD

S obzirom na novije izazove tehnologije sadašnjice i kreiranja budućih tokova, ekonomija se je predodredila na online berze. Međutim, predviđanje dionica tržišta je ne predvidivo. Značajna istraživanja se vrše u predviđanju dionica, kako bi se osigurala zarada korištenjem različitih statističkih metoda, tehničkih analiza među podacima. Ove tehnike ne mogu omogućiti detaljniju analizu koja je neophodna u cilju efektivnijeg predviđanja dionica i

cijena na tržištu [8]. Primjna vještačke inteligencije (Artificial Neural Network – ANN) jedna je od metoda koja se je značajno primjenjuju u istraživanjima poslovnih okruženja iz razloga da se kreira mogućnost učenja i detektovanja relacija među ne linearnim varijablama. Zapravo, vještačka inteligencija omogućava detaljniju analizu veće količine podataka, posebno onih podataka koji imaju tendenciju mijenjanja. Zbog toga ovo sve upućuje nas na korištenje primjene vještačke inteligencije neuronskih mreža [7,6]. Poslovno okruženje današnjice, prolazi kroz transformaciju poslovanja posljednjih deset godina i vještačke neuronske mreže su se pokazale kao model koji se u velikom broju koristi u biznisu, finansijama, ekonomiji s ciljem predviđanja serija performanci mjerenja. Brzine promjena koje se dešavaju, danas putem virtuelnih rješenja su promijenile tokove tradicionalnih berzi. Dobra primjer u Bosni i Hercegovini je Sarajevska – berza (SASE) firma, koja omogućuje da se prate stanja na berzi u realnom vremenu. Međutim, stanje na berzi od posebnog je značaja za investitore. Bosna i Hercegovine zemlja je u razvoju i ovaj rad ima za cilj da ponudi jedan poduhvat u istraživanju da ponudi modele koji će investitorima pored stanja na berzi moći ponuditi jedan i prediktivni model koji će biti analiziran na osnovu resursa, a u cilju predviđanja stanja berze, dionica, dividendi a sve s ciljem što boljeg ulaganja u BiH. U svijetu berze su u jednom haotičnom sistemu zbog svih podataka koji prolaze kroz taj sistem. Istraživači nastoje da pronađu model koji bi omogućio da se ne predviđeni tokovi analiziraju i omoguće predviđanja. Nastojaćemo da predstavimo uvod u metodologiju neuronskih mreža, predviđanje dionica i rezultate testirane u MATLAB-u.

2. METODOLOGIJA

2.1. Šta je neuronska mreža?

Vještačke neuronske mreže su nastale od vještačkih neurona. Neuroni su najmanje procesne jedinice i osnova su neuronskih mreža [9]. Najveća prednost neuronskih mreža je mogućnost modeliranja kompleksnih ne linearnih sistema sa pretpostavkom prirodne relacijske veze neuronske mreže gdje neuronska mreža ima tri nivoa: **ulazni sloj**, **skriveni sloj** i **izlazni sloj**. *Ulazni sloj* samo prikuplja unesene podatke i ponaša se kao ne zavisna varijabla tako da količina neurona zavisi od broja unesenih varijabli. *Izlazni sloj* se zavisana varijabla i količina neurona u ovom sloju zavisi od varijabli od kojih je on zavisan a to su i tzv. previđajuće varijable. Za broj skrivenih neurona preporučuje se da broj skrivenih slojeva bude: $2n + 1$; $2n$; n ; $n/2$, gdje je n broj neurona u ulaznom sloju, a najbolji izbor je, da broj neurona u ovom sloju bude baziran na probi i greški. Zapravo podaci trebaju da budu podjeljeni u dva seta: *training set* i *testing set*. Potom podaci koji se nalaze u setu za treniranje neuronske mreže, na osnovu njih se određuje ponašanje serija, te se onda kompletna neuronska mreža upoređuje s izlaznim podacima i stvarnim podacima koji se nalaze u testnom skupu. Čak pojedini istraživači preporučuju da se podaci podjele u tri faze i to: *treniranje*, *validacija* i *testiranje*.

Figura 1, prikazuje jednostavanu neuronsku mrežu sastavljenu od pet neurona. Četiri neurona W, X, Y, Z, predstavljaju ulaze, dok peti neuronon, odnosno N, predstavlja izlaz. Svaki od ovih neurona može "ispaliti" impuls ili ne ispaliti impuls. Pritom svaka veza među neuronima ima određenu težinu. Ukupni otežani ulaz u N zapravo je zbroj težina svih veza koje vode do N, a kojima je ispaljen impuls. Tako, npr., ako ulazni neuroni X i Y ispale impuls, pošto su težine veza između X i N 1,5, i između Y i N 0.5 čime ukupni otežani ulaz u N iznosi 2, neuron N neće ispaliti impuls, jer prag osjetljivosti je 5, što znači da ukupno otežani ulaz u N mora biti veći ili jednak od 5 da bi neuron ispalio impuls. N će ispaliti impuls ako npr. neuroni W i Z ispale impuls ili npr., neuroni W, X i Y. Neuronske mreže imaju dvije ključne karakteristike, a to su sposobnost paralelnog procesiranja, te distribuiranost znanja kroz

mrežu. Svaki je neuron zapravo jednostavni procesor koji podatke može procesirati istovremeno kada i drugi neuroni u mreži. Distribuiranost znanja kroz mrežu se pak očituje u nepostojanju zasebne memorije za pohranjivanje podataka. Umjesto toga podaci (znanje) se u mreži pohranjuju u obliku vrijednosti težina veza, što je ekvivalent načinu pohranjivanja znanja u ljudskome mozgu.

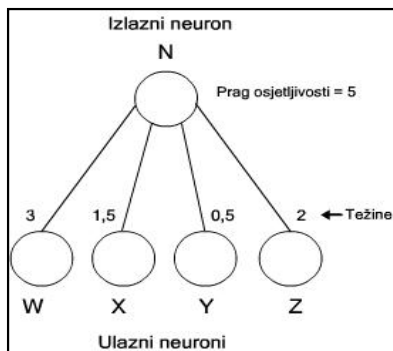


Figura 1. Model Neurosnke Mreže

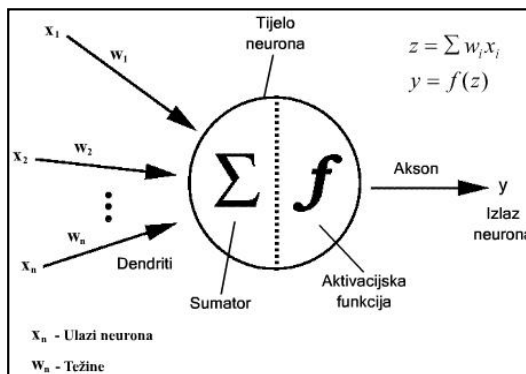


Figura 3. Vještački model neurosnke mreže

2.2. Vještački neuronski model

Figura 2, prikazuje najjednostavniji oblik vještačkog neurona, tj. perceptrona. S obzirom da vještački neuron simulira biološki neuron, njegove dijelove možemo usporediti sa djelovima biološkog neurona. Ekvivalent tijela biološkog neurona je sumator umjetnog neurona, aksona izlazi sumatora, a dendriti uzlazi u sumator. Ulazne vrijednosti neurona (x_1, x_2, \dots, x_n) množe se sa odgovarajućim težinama (w_1, w_2, \dots, w_n). Težine su ekvivalent snage sinapsi kod biološkog neurona. Vrijednost težine može biti pozitivan ili negativan broj. U sumatoru se vrši sumiranje otežanih signala, a rezultat sumiranja čini izlaz iz sumatora, koji je ujedno i ulaz u aktivacijsku funkciju. Aktivacijska funkcija je ekvivalent praga osjetljivosti biološkog neurona, a može biti linearna ili nelinearna. Kod perceptrona se koristi jednostavna funkcija praga (threshold - stepwise - function) koja kao izlaze daje 0 ili 1. Kao aktivacijske funkcije također se mogu koristiti i druge funkcije kao npr., sigmoidalna, tanh i signum funkcija. U našim istraživanjima za testiranje i simulaciju smo koristili MATLAB. Figura 4 prikazuje vještačku neuronsku mrežu u MATLAB-u. Figura 3, prikazuje ulaznu (input) varijablu, skriveni sloj (hidden layer), treniranje (output layer) i izlazni sloj (output).




Figura 4. Vještački model neurosnke mreže u MATLAB-u

3. VJEŠTAČKE NEUROSNKE MREŽE I NJIHOVA PRIMJENA

Investitori koji ulazu na berzi i koji trguju dionicama primarno to rade na svojoj intuiciji, prije nego je došlo do napretka u razvoju računara. Kontinuirana povećanost investiranja i trgovanja berzama zahtjeva da se radi na pronalasku vještačkog modelada poboljša vjerovatnoću predviđanja berze. Statistika, tehnička analiza, teorija haosa, linearna regresija, serije su sve tehnike koje su prihvaćene za predviđanje kretanja tržišta. Međutim, ni jedna od ovih tehnika nije u mogućnosti da konstantno daje tačna predviđanja na berzi, i mnoge analize još uvijek nisu u potpunosti istražene ni razvijene da bi bile korisne. Ali, ove metode

predstavljaju najbolji model kao standard, koje neurosnke mreže trebaju da proizvedu u predviđanju berze.

3.1. Eksperiment i testiranje u MATLAB-ovom tool box-u

Prema [8], White koji je objavio prvu značajnu studiju o aplikacijama neuronskih mreža za predviđanje kretanja cijena na berzi. Prateći Whitovu studiju, nekoliko značajnih istraživačkih poduhvata je urađeno da bi se ispitalo predviđanje i efikasnost neuronskog modela mreža na berzama. Drugi značajn doprinos je dao Yoda [7] u istraživanju predviđanja kapaciteta neuronskih mreža za Tokyo berzu. Također, model neuronskih mreža je korišten u različitim US berzama gdje se je mjerio povrat dobiti na uloženu investiciju. Kako je prikazano u [1] različita su istraživanja predviđanja berzi sa različitim aplikacijama neuronskog modela. Neke istraživanja smatraju da je efektivnost u modeliranju neuronske mreže. Drugo istraživanje zalaže teoriju da efikasnost predviđanja zavisi od: arhitekture [4,5], treniranja algoritma [2], ulaznih varijabli [3].

U ovom radu mi smo radili testiranja sa ulaznim varijablama s SASE berze za pet bosanskohercegovačkih firmi: Bosnalijek d.d. Sarajevo, Tvornica cementa Kakanj d.d., Kakanj, BH Telecom d.d. Sarajevo, Energoinvest d.d. Sarajevo, JP Elektroprivreda BH d.d. Sarajevo, Hidrogradnja d.d. Sarajevo, Energopetrold d.d. Sarajevo. Nastojali smo da uradimo testiranje modela neurosnke mreže kako je prikazan na Figuri 3., gdje smo uzeliu razmatranje sljedeće:

1. **Zarada po dionici:** zarada po dionici je jedna od najvažnijih mjerenja kada je u pitanju jačina kompanije. Značaj zarade po dionici je očito jer od toga zavisi koliko dobit kompanija može generisati. Gubljenje novca će prouzrokovati bankropt, tako da jedini način za duže preživljavanje firme se zasniva na zaradi.
2. **Predviđanje zarade po dionici:** Predviđanje zarade po dionici je uvijek nerealno, te ne postoji tačni mehanizmi koji bi nam mobil pomoći u predviđanju kretanja cijena
3. **Dividenda po dionici:** Dividende po dionici su ukupan broj plaćenih dividendi u cijeloj godini.

Tabela 1: Cijene dionica preuzeta sa SASE online stranice; predviđene cijene generisane u MATLABU u neronon network toolbox-u

Ime Firme	Predviđena cijena	Stvarna cijena
Bosnalijek d.d. Sarajevo	7,60	10
Tvornica cement Kakanj d.d.	18,19	19,51
BH Telecom d.d. Sarajevo	17,32	19,70
Energoinvest d.d. Sarajevo	3,55	3,80
JP Elektroprivreda BH d.d. Sarajevo	18,05	18,89
Hidrogradnja d.d. Sarajevo	1,85	1,92
Energopetrol d.d. Sarajevo	10,1	10,20

U tabeli 1, prikazan je samo primjer podataka na osnovu kojih smo generisali neuronsku mrežu. Podatke smo koristili sa Sarajvske Berze – Burze (SASE), te smo za simulaciju koristili raspon od 20 dana. Generisali smo ulazne i izlazne podatke. Vjerujemo da s većim brojem podataka bi mogli imati i bolje rezultate, međutim koristili smo ovo kao polaznu tačku za dalje istraživanje. Figura 5, prikazuje grafički prikaz podataka u vrijeme testiranja, treninga, i validiranja podataka koji su neophodni pri kreiranju modela vještačke neurosnke mreže. Također smo mjerili efikasnost pa u Figuri 6 je prikazana efikasnost performansi.

Zapravo možemo da vidimo da dolazi do blagog odstupanja podataka koji su u fazi testiranja u odnosu na trenirane ulazne varijable.

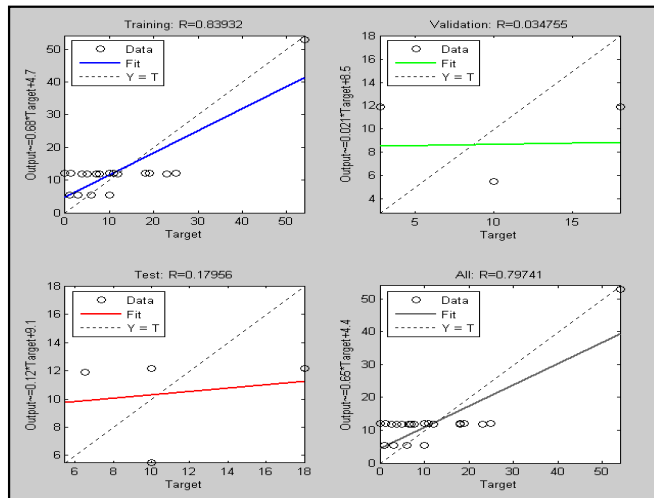


Figura 5. Grafički prikaz testiranih, treniranih i validiranih ulaznih podataka, na osnovu koje je gensina vještačka mreža




Figura 6. Upoređivanje efikasnosti performansi treniranja, validacije, testiranja podataka putem neuronske mreže

4. ZAKLJUČAK

Ovaj rad imao je za cilj, da predstavi uvod jedan vještački model, način, predviđanja cijena na tržištu kombinacijom tehnika neuronskih mreža s ulaznim varijablama (cijenama). U testiranju je primjenjen model neuronske mreže sa primjenom Matlab tool boxa. Vještački model u budućnosti ima potencijala da unaprijedi i da pomogne predviđanje kretanja cijena na tržištu, da omogući kvalitet pri donošenju odluka za investitore koji ulažu na berzu. Imamo namjeru da radimo na istraživanju kritičkih tačaka u predviđanju kao baze za predviđanje cijena na tržištu berze.

U budućnosti neurosnke mreže će biti neizbježan faktor kako u poslovnom okruženju tako i u istraživačkom, gdje će se investitorima omogućiti bolji kvalitet poslovanja tržišta. Jedan od glavnih faktora u budućem istraživanju bit će kako unaprijediti bolju mrežnu arhitekturu vještačke mreže. Trenutna istraživanja i testiranja koja smo proveli, pokazuju da još uvijek dolazi do blagog odstupanja s greškom kada se primjenjuje neurosnka mreža u predviđanju tržišta. Međutim, moramo da imamo na umu, da tržište je jedan ne predviđeni model, te da buduća neurosnka mreža treba da bude omogućena da kontinuirano uči na osnovu svakog primjera, tj. da kreiramo bazu na osnovu koje će vještački model učiti.

S obzirom da su berze današnjice predstavljen online, već sad bi se mogli neurosnki model povezati s online sistemom, te neuronskoj mreži omogućiti kontinuirano učenje na osnovu čega bi pružila bolje performanse u pogledu predviđanja tržišta u budućnosti. Pri istraživanju smo došli i do zaključka da su neorsne mreže i samo neuronsko učenje jedan haotičan sistem, te da će biti neophodno dalje nastaviti raditi unapređenja u ovom polju. Testiranje smo radili na jednom malom primjeru, da ispitamo primjenu *vještačke neurosnke mreže*, i *performanse* te kako one rade u finansijskom sistemu. Kao što možemo da vidimo iz rada, ne možemo se osloniti na prediktivne modele ponuđene neurosnkim mrežama, ali možemo raditi na istraživanju, kako bi dostigli jedan zavidan nivo, gdje bi neurosnke mreže omogućile metode predviđanja berze s malim procentom greške.

5. LITERATURA

- [1] M.T. Philip, K. Paul, S.O. Choy, K. Reggie, S.C. Ng, J. Mark, T. Jonathan, K. Kai, i W. Tak-Lam, „Design and implementation of NN5 for Hong Stock Price Forecasting“, Journal of Engineering Applications of Artificial Intelligence, vol. 20, 2007, str.453-461.
- [2] E. Avci, “Forecasting Daily and Sessional Return of the Ise – 100 Index with Neural Network Models”, Dogus Universitesi Dergisi, vol. 2., br. 8, 2007, str.128-142.
- [3] D. Brownstone, “Using Percentage Accuracy to measure Neural Network Predictions in Stock market Movements”, Journal of Neurocomputing, br. 10, 1996, str. 38-44.
- [4] Y.F. Sun, Y.C. Liang, W.L. Zhang, H.P. Lee, W.Z. Lin i L.J. Cao, “Optimal Partition Algorithm of the RBF Neural Network and Its Application to Finacial Time Series Forecasting”, Neural Computation and Application, 2006, str. 36-44.
- [5] K. Kohara, T. Ishikawa, Y. Fukuhara, and Y. Nakamura, “Stock Price Prediction using Prior Knowledge and Neural Networks”, Intelligent Systems in Apccounting, Finance and Management, br. 6, 1997, str. 11-22.
- [6] S.H. Kim, i S.H. Chung, “Graded Forecasting using Arraz of Bipolar Predictions: Application of probabilistic neural Networks to a Stock Market Index”, International Journal of Forecasting, br. 14, 1998, str. 323-337.
- [7] A. Ayodel, A. Charles, A. Marion, i S. Otokiti, “Stock Price Prediction using neural Network with Hybridized market Indicators” Journal of Emerging Trends in Computing and Information Sciences, vol. 3. Br. 1, 2012.
- [8] Z.H. Khan, T.S. Alin, M.A. Hussain, “Price Prediction of Share using Artificial Neural network (ANN)”, International Journal of Computer Application, vol. 22. Br. 2, 2011.
- [9] Wu, S.I., „Artificial neural networks in forecasting, neural networks world“, 2(IDGVSP) 1995, str. 199-220.